

Modeling Groundwater Quality Changes Using Optimized Artificial Neural Network Model (Case Study: Zeidoun plain)

Seyed Ali Mohammadi Nezhad

MS.c Student, Department of Civil Engineering,
Ahvaz Branch, Islamic Azad University,
Ahvaz, Iran.

Aslan Egdernezhad

* Assistant Professor, Department of Water
Sciences and Engineering, Ahvaz Branch,
Islamic Azad University, Ahvaz, Iran.
(Corresponding Author):
Email: a_eigder@gmail.com

Received: 2021/08/04

Accepted: 2021/12/14

Document Type: Research article

ABSTRACT

Background and Aim: One of the main aims of water resource planners and managers is the estimation and prediction of groundwater quality parameters to make managerial decisions. In this regard, many models have been developed with better management proposals for maintaining water quality. Most of these models require input parameters which are either hardly available or their measurements are time consuming and expensive. Among these models, Artificial Neural Network (ANN) models inspired by human's brain are a better alternative. The objective of this study was to model ground water quality changes using an optimized artificial neural network model.

Materials and methods: The present study stimulated the groundwater quality parameters of Zeidoun plain including Sodium Adsorption Ratio (SAR), Electrical Conductivity (EC), Total Dissolved Solids (TDS), and ANN and ANN-GA models; the obtained results were ultimately compared with the measured data. From 2011 to 2018, we gathered the input data for TDS quality parameter consisting of Na, EC, Ca, Mg, SO_4 and SAR, for SAR including Na, TDS, HCO_3 , Ca and Mg and the quality parameters of EC containing Ca, Mg, SO_4 , Na and SAR.

Results: Based on the results, in ANN and ANN-GA models, the highest accuracy of SAR simulation belonged to the model with sigmoid tangent function, and in EC simulator model, the highest accuracy in ANN and ANN-GA models was related to logarithm stimulus functions. Also, in ANN and ANN-GA models, the highest accuracy of TDS simulation was obtained in the model with sigmoid tangent stimulus and sigmoid logarithm, respectively. Therefore, the MAE and RMSE statistics had the minimum and had the maximum value for the model. In general, according to the obtained results, the accuracy of ANN-GA model for simulating the groundwater quality parameters of Zeidoun plain was higher than ANN model.

Conclusion: Accordingly, the use of artificial neural network model along with genetic algorithm is a good approach to simulating high quality groundwater quality parameters with out the need for measurement and laboratory work which are time-consuming and costly.

Keywords: Groundwater, Quality Parameters, Simulation, Artificial Neural Network

► **Citation:** Mohammadi Nezhad SA, Egdernezhad A. Modeling Groundwater Quality Changes Using Optimized Artificial Neural Network Model (Case Study: Zeidoun plain). *Journal of Research in Environmental Health*. Winter 2022; 7(4): 311-322.

مدل سازی تغییرات کیفی آب زیرزمینی با استفاده از مدل شبکه عصبی مصنوعی بهینه شده (مطالعه موردی: دشت زیدون)

سید علی محمدی نژاد

دانشجوی کارشناس ارشد، گروه مهندسی عمران، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران.

اصلان آگدرنژاد

* استادیار، گروه علوم و مهندسی آب، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران.

(نویسنده مسئول):

پست الکترونیک:

a_eigder@ymail.com

تاریخ دریافت: ۱۴۰۰/۰۵/۱۳

تاریخ پذیرش: ۱۴۰۰/۰۹/۲۳

نوع مقاله: مقاله پژوهشی

چکیده

زمینه و هدف: برآورد و پیش‌بینی پارامترهای کیفی آب زیرزمینی به‌منظور تصمیم‌گیری‌های مدیریتی، یکی از اهداف مدیران و برنامه‌ریزان منابع آب تلقی می‌گردد. در این راستا تعداد زیادی مدل در زمینه مدیریت بهتر برای حفظ کیفیت آب گسترش یافته است. بیشتر این مدل‌ها نیازمند پارامترهای ورودی هستند که یا دسترسی به آنها مشکل است و یا اینکه اندازه‌گیری آنها محتاج صرف هزینه و زمان زیادی می‌باشد. در این میان مدل‌های شبکه عصبی مصنوعی که با الهام از ساختار مغز بشر عمل می‌نمایند، به‌عنوان گزینه‌ای برتر معرفی می‌شوند. مطالعه حاضر با هدف مدل‌سازی تغییرات کیفی آب زیرزمینی با استفاده از مدل شبکه عصبی مصنوعی بهینه شده، انجام شد.

مواد و روش‌ها: پژوهش حاضر به‌منظور شبیه‌سازی پارامترهای کیفی آب زیرزمینی دشت زیدون شامل نسبت جذب سدیم، هدایت الکتریکی و کل جامدات محلول با استفاده از مدل‌های شبکه عصبی مصنوعی و مدل شبکه عصبی تلفیقی با الگوریتم ژنتیک و در نهایت مقایسه نتایج آن‌ها با داده‌های اندازه‌گیری شده انجام گرفت. پارامترهای ورودی مدل‌ها برای پارامتر کیفی TDS شامل: سدیم، هدایت الکتریکی، کلسیم، منیزیم، سولفات و نسبت جذب سدیم، برای پارامتر کیفی SAR شامل: سدیم، کل نمک‌های محلول، بی‌کربنات، کلسیم و منیزیم و برای پارامتر کیفی EC شامل: کلسیم، منیزیم، سولفات، سدیم و نسبت جذب سدیم از سال ۱۳۹۰ تا ۱۳۹۷ جمع‌آوری گردید.

یافته‌ها: در مدل ANN و ANN-GA بیشترین دقت شبیه‌سازی SAR در مدل با تابع تانژانت سیگموئید و در مدل شبیه‌ساز EC نیز بیشترین دقت در مدل‌های ANN و ANN-GA به‌ترتیب مربوط به توابع محرک لگاریتم سیگموئید و تانژانت سیگموئید بود. همچنین در مدل ANN و ANN-GA بیشترین دقت شبیه‌سازی TDS به‌ترتیب در مدل با توابع محرک تانژانت سیگموئید و لگاریتم سیگموئید به‌دست آمد؛ به‌طوری‌که مقدار RMSE و MAE کمترین مقدار و شاخص R^2 بیشترین مقدار را داشت. به‌طور کلی با توجه به نتایج به‌دست آمده، دقت مدل ANN-GA نیز بالاتر از مدل ANN، برای شبیه‌سازی پارامترهای کیفی آب زیرزمینی دشت زیدون برآورد شد.

نتیجه‌گیری: استفاده از مدل شبکه عصبی مصنوعی به‌همراه الگوریتم ژنتیک، ابزار مناسبی برای شبیه‌سازی پارامترهای کیفی آب زیرزمینی در حجم بالا، بدون احتیاج به اندازه‌گیری و کارهای آزمایشگاهی است که نیاز به زمان و هزینه بالا دارند.

کلید واژه‌ها: آب زیرزمینی، پارامترهای کیفی، شبیه‌سازی، مدل شبکه عصبی مصنوعی

◀ **استناد:** محمدی‌نژاد س ع، آگدرنژاد الف. مدل‌سازی تغییرات کیفی آب زیرزمینی با استفاده از مدل شبکه عصبی مصنوعی بهینه شده (مطالعه موردی: دشت زیدون). فصلنامه پژوهش در بهداشت محیط. زمستان ۱۴۰۰؛ ۷(۴): ۳۱۱-۳۲۲.

مقدمه

ورودی دما، کدورت، اسیدیت و هدایت الکتریکی استفاده کردند و از شبکه پرسپترون در مطالعه خود استفاده نمودند. نتایج این تحقیق نشان داد از شبکه عصبی مصنوعی می توان به عنوان ابزاری مناسب برای تخمین میزان اکسیژن محلول استفاده کرد (۷). منتسری و همکاران به منظور مدل سازی کل جامدات محلول از مدل شبکه عصبی مصنوعی، مدل فازی، برنامه ریزی ژنتیک و هیبرید استفاده نمودند. نتایج مطالعه آنها نشان دهنده برتری مدل ژنتیک برای شبیه سازی کل جامدات محلول در منطقه مورد مطالعه بود (۸).

با توجه به مطالعات انجام شده، اهمیت ویژه شبیه سازی و پیش بینی پارامترهای کیفی آب زیرزمینی به دلیل صرفه جویی در هزینه و زمان مشخص می گردد. از آن جایی که تعداد مطالعات مورد بررسی با الگوریتم های بهینه سازی محدود هستند، در این پژوهش از مدل شبکه عصبی مصنوعی (ANN)^۱ و مدل شبکه عصبی مصنوعی تلفیق شده با الگوریتم ژنتیک (ANN-GA)^۲ برای شبیه سازی پارامترهای کیفی آب زیرزمینی (EC^۳، TDS^۴ و SAR^۵) دشت زیدون استفاده شد.

منطقه مورد مطالعه


حوضه آب ریز زیدون در مختصات جغرافیایی ۵۰ درجه و ۱۵ دقیقه تا ۴۹ درجه و ۴۲ دقیقه عرض شمالی و ۳۰ درجه و ۱۶ دقیقه تا ۳۰ درجه تا ۴۱ دقیقه طول شرقی در جنوب غرب شهرستان بهبهان و فاصله تقریباً ۱۸۰ کیلومتری شهرستان اهواز در استان خوزستان واقع شده است. محدوده مطالعاتی با مساحتی در حدود ۱۱۷۸ کیلومتر مربع، به ۵۰ زیرحوضه تقسیم می گردد. رودخانه زهره و خیرآباد، مهم ترین و اصلی ترین رودخانه های این حوضه هستند. رودخانه خیرآباد پس از تلاقی با رودخانه زهره با نام رود زهره (هندیجان)، با روند تقریباً جنوب شرقی- شمال غربی از مرکز دشت زیدون عبور می نماید.

آب های زیرزمینی به عنوان تنها منبع مورد اعتماد مصرف آب در زمینه های شرب، کشاورزی و صنعت در مناطق خشک و نیمه خشک محسوب می شود (۱). در سال های اخیر برداشت بی رویه از منابع آب زیرزمینی از یک سو و فعالیت در جهت تأمین غذا از سوی دیگر، باعث لطمات جبران ناپذیری به این منابع از نقطه نظر کمی و کیفی گردیده است (۲)، لذا مطالعات کیفی آب زیرزمینی حائز اهمیت می باشند. از طرفی مدل های رایانه ای، ابزاری مناسب برای مدیریت منابع آب فراهم نموده اند و امروزه استفاده از مدل های ریاضی نرم افزاری برای پایش و مدیریت منابع آب زیرزمینی توسعه چشم گیری یافته است. مدل های بسیاری برای بررسی و پیش بینی کیفیت آب مورد استفاده قرار می گیرند که بیشتر آن ها نیازمند اطلاعات ورودی فراوان و غیرقابل دسترس هستند و یا اندازه گیری این اطلاعات، صرف هزینه های زمانی و مالی فراوانی را به دنبال خواهد داشت (۳). تکنولوژی شبکه های عصبی مصنوعی و همچنین تلفیق آن با الگوریتم های بهینه سازی، نتایج رضایت بخشی را در مدل سازی سیستم های پیچیده غیرخطی در مسائل هیدرولوژی و مدیریت منابع آب نشان داده است که به تفصیل توسط محققان در حوزه های مختلف گزارش شده است (۴). در مطالعه صیادی شهرکی و همکاران که به شبیه سازی بار هیدرولیکی و شوری آب زیرزمینی با استفاده از شبکه عصبی مصنوعی و الگوریتم بهینه سازی ذرات در کشت و صنعت نیشکر دعبیل خزاعی پرداختند، دقت مدل شبکه عصبی آموزش داده شده با الگوریتم بهینه سازی تجمع ذرات بالاتر از مدل شبکه عصبی مصنوعی با آموزش پس انتشار خطا بود (۵). نتایج مطالعه روکی و همکاران که به بررسی کیفیت آب زیرزمینی آبخوان دشت گناباد با استفاده از روش های آماری چندمتغیره و هوش مصنوعی پرداختند، نشان داد که مدل شبکه عصبی مصنوعی قابلیت بالایی برای پیش بینی پارامترهای کیفی آب زیرزمینی دارد (۶). کاند و همکاران به منظور بررسی توانایی مدل شبکه عصبی در تخمین میزان اکسیژن محلول در رودخانه انزویا در کنیا، از چهار متغیر

1. Artificial neural network
2. Artificial neural network- Genetic algorithm
3. Electrical Conductivity
4. Total Dissolved Solids
5. Sodium Adsorption Ratio

دریا می‌باشد. پست‌ترین نقطه ارتفاعی در این حوضه آبریز با ارتفاع ۵ متر از سطح دریا در قسمت خروجی دشت واقع شده است. شکل ۱، موقعیت منطقه مورد مطالعه در شهرستان بهبهان و استان خوزستان را نشان می‌دهد.

منطقه مورد مطالعه از شمال به محدوده مطالعاتی بهبهان، از شرق به محدوده مطالعاتی خیرآباد، از جنوب به استان بوشهر و از غرب به محدوده مطالعاتی هندیجان، محدود می‌گردد. بلندترین نقطه ارتفاعی در این حوضه آبریز در ارتفاع ۴۹۰ متری از سطح



شکل ۱. موقعیت منطقه مورد مطالعه در شهرستان بهبهان



شکل ۲. نحوه پراکنش چاه‌های منطقه مورد مطالعه

تلاش می‌کند تا با شناخت روابط ذاتی بین داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. لایه یا لایه‌های مخفی، اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهند. هر شبکه با دریافت مثال‌هایی آموزش می‌بیند. آموزش فرآیندی است که در نهایت منجر به یادگیری می‌گردد. یادگیری شبکه، زمانی انجام می‌شود که وزن‌های ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف بین مقادیر پیش‌بینی شده و محاسبه شده در حد قابل قبولی باشد. با دستیابی به این شرایط، فرآیند یادگیری محقق


روش کار

از آنجایی که برای رسیدن به دقت قابل قبول مدل‌ها و اهداف پژوهش، نیاز به اندازه‌گیری بلندمدت داده می‌باشد، تمام پارامترهای ورودی مدل شامل: هدایت الکتریکی، نسبت جذب سدیم، اسیدیته، سولفات، کلسیم، منیزیم، سدیم، مقدار کل نمک‌های محلول و بی‌کربنات از دشت زیدون طی سال‌های ۱۳۹۰ تا ۱۳۹۷ از ۱۸ حلقه چاه مشاهده‌ای به‌صورت ماهانه از سازمان آب و برق خوزستان دریافت و به کمک نرم‌افزار اکسل و SPSS22، دسته‌بندی و آنالیز گردید. با استفاده از مدل شبکه عصبی مصنوعی و الگوریتم ژنتیک، پارامترهای کیفی آب زیرزمینی شامل EC، SAR و TDS در نرم‌افزار Matlab شبیه‌سازی شد. سپس دقت پیش‌بینی‌های دو مدل محاسبه و با مقادیر واقعی اندازه‌گیری و مقایسه گردید. نحوه پراکنش چاه‌های منطقه مورد مطالعه در شکل ۲ نشان داده شده است.

مدل شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی، یکی از روش‌های محاسباتی است که به کمک فرآیند یادگیری و با استفاده از پردازشگرهایی به نام نرون

خروجی نرون ها در لایه خروجی، (ت) - بهنگام سازی وزن ها به روش انتشار خطای شبکه به لایه های قبل که خطای یاد شده ناشی از اختلاف بین خروجی واقعی و خروجی محاسبه شده است، (ث) - ارزیابی عملکرد شبکه آموزش دیده به کمک برخی شاخص های تعریف شده مانند جذر میانگین مربعات خطا و سرانجام برگشت به قسمت پ یا پایان آموزش می باشد (۹، ۱۰). تابع انتقال، مجموع ورودی وزن دار را به خروجی نرون نگاشت می کند. به این تابع، بدین دلیل تابع انتقال گفته می شود که آغازی که در آن نرون فعال می شود را کنترل کرده و سیگنال خروجی را قدرت می بخشد. شکل ۳، نمایی از یک شبکه پرسپترون چند لایه را نشان می دهد.



شکل ۳. نمایی از یک شبکه پرسپترون چند لایه

شبکه عصبی مصنوعی تأثیرگذار باشند. در این پژوهش به منظور شبیه سازی پارامترهای سطح آب زیرزمینی و شوری آب زیرزمینی، به مقایسه دو مدل ANN و ANN-GA پرداخته شد. خروجی هر کدام از مدل ها برای هر دو پارامتر هدف به ازای دو تابع محرک به دست آمد. سپس با توجه به معیارهای ارزیابی مدل، سناریویی که دارای کمترین مقدار خطا در دوره های آموزش و تست بود، به عنوان ساختار بهینه انتخاب شد. همچنین ۷۵٪ داده ها برای آموزش، ۱۰٪ صحت سنجی و ۱۵٪ برای تست در نظر گرفته شد.

الگوریتم ژنتیک^۲


الگوریتم ژنتیک، از اعضای خانواده مدل های محاسباتی می باشد که الهام گرفته از روند تکاملی است. این الگوریتم ها راه حل های

شده است. این وزن ها، حافظه و دانش شبکه را بیان می کنند. شبکه عصبی آموزش دیده می تواند برای شبیه سازی خروجی های متناسب با مجموعه جدید داده ها به کار رود (۹). از ویژگی های عمده و اساسی مدل شبکه عصبی مصنوعی، سرعت بالای پردازش، توانایی یادگیری الگو به روش اراده الگو، توانایی تعمیم دانش پس از یادگیری، انعطاف پذیری در برابر خطاهای ناخواسته و عدم ایجاد اختلال قابل توجه در صورت بروز اشکال در بخشی از اتصال ها به دلیل توزیع وزن های شبکه است (۱۰). مراحل آموزش به کمک این الگوریتم شامل: (الف) - اختصاص ماتریس وزن تصادفی به هر یک از اتصالات، (ب) - انتخاب بردار ورودی و خروجی متناسب با آن، (پ) - محاسبه خروجی نرون در هر لایه و در نتیجه محاسبه

یکی از چالش های موجود در شبکه های عصبی مصنوعی، مسئله آموزش آن می باشد. شبکه می بایست ابتدا آموزش ببیند و سپس بر اساس اندوخته هایش عمل نماید. روش های آموزش آماری همچون پس انتشار خطا^۱ دارای سرعت پایین و همگرایی به بهینه محلی می باشد. یکی از روش های مناسب برای رفع این مشکل، استفاده از سیستم های ترکیبی است؛ به این ترتیب که شبکه عصبی مصنوعی با استفاده از یک روش بهینه سازی مناسب آموزش داده می شود (۵). در انجام این پژوهش با استفاده از آموزش به روش الگوریتم بهینه سازی ازدحام ذرات تلاش می شود این مشکل برطرف شود. همانطور که گفته شد، نحوه آموزش مدل و تابع محرک، از مهم ترین پارامترهایی هستند که می توانند در خروجی مدل

جمعیت می‌نامند. این الگوریتم با تولید نسل آغاز و جمعیت اولیه را به صورت انتخابی یا تصادفی ایجاد می‌نماید (۱۱). از آنجایی که الگوریتم برای هدایت عملیات جستجو به سمت نقطه بهینه، از روش‌های آماری استفاده می‌کند، جمعیت موجود به تناسب برازندگی افراد آن، برای نسل بعد انتخاب می‌شوند. سپس عملگرهای ژنتیکی اعمال و جمعیت جدید ایجاد شده و چرخه ادامه می‌یابد. معمولاً جمعیت جدید برازندگی بیشتری داشته و از نسلی به نسل دیگر بهبود می‌یابد. جستجو زمانی خاتمه می‌یابد که به حداکثر نسل ممکن رسیده و یا همگرایی حاصل شده باشد. شکل ۴ نمای کلی ژنتیک را نشان می‌دهد.

بالقوه یک مسأله را در قالب کروموزوم‌های ساده‌ای کد کرده و سپس عملگرهای ترکیبی را بر روی این ساختارها اعمال می‌نماید. الگوریتم ژنتیک اغلب به عنوان روشی مبتنی بر جستجوی تصادفی برای بهینه‌سازی و شبیه‌سازی پارمترها به کار می‌رود. اساس این الگوریتم، قانون تکامل داروین است که بیان می‌کند: موجودات ضعیف‌تر از بین رفته و موجودات قوی‌تر باقی خواهند ماند. در الگوریتم ژنتیک، مجموعه متغیرهای طراحی شده توسط رشته‌هایی با طول ثابت یا متغیر کدگذاری می‌شوند که به آن‌ها کروموزوم یا فرد می‌گویند. هر رشته یا کروموزوم، یک نقطه پاسخ در فضای جستجو را نشان می‌دهد. هر مرحله تکرار نیز نسل و مجموعه‌هایی از پاسخ‌ها در هر نسل را



شکل ۴. نمای کلی الگوریتم ژنتیک

با مروری بر منابع موجود از جمله موسوی جهرمی و گلابی (۱۲) و بانژاد و همکاران (۱۳)، می‌توان نتیجه گرفت که انتخاب پارامترهای TDS ، SO_4^{2-} ، Ca^{2+} ، Mg^{2+} ، Na^+ ، HCO_3^- ، pH ، EC و SAR در شبیه‌سازی پارامترهای کیفی مورد بحث، نتایج خوبی را ارائه نموده است، لذا ترکیب‌های مختلف همین پارامترها به‌عنوان ورودی مدل‌ها استفاده گردید.

محاسبه ضریب همبستگی

آنالیز میزان همبستگی بین متغیرهای ورودی و متغیر هدف کاری مفید است، زیرا اطلاعات ارزشمندی در خصوص میزان وابستگی هر کدام از پارامترهای ورودی نسبت به پارامتر هدف در اختیار می‌گذارد. در جدول ۲ همبستگی بین EC ، TDS و SAR و پارامترهای ورودی مدل‌های هر کدام نشان داده شده است.

جدول ۲. میزان همبستگی پیرسون بین EC ، TDS و SAR با پارامترهای ورودی مدل‌ها

متغیر	Na^+	Ca^{2+}	Mg^{2+}	SO_4^{2-}	HCO_3^-	pH	EC	TDS	SAR
EC	۰/۷۹۵۰	۰/۹۰۱۰	۰/۸۲۵۰	۰/۸۰۱۰	۰/۴۸۰	-۰/۲۰۵	۱	۰/۴۲۱	۰/۶۴۰
TDS	۰/۸۸۹۰	۰/۶۹۸۰	۰/۶۰۱۰	۰/۵۹۹۰	۰/۲۱۰	۰/۱۱۹	۰/۷۴۰	۱	۰/۵۵۷
SAR	۰/۷۷۰	۰/۵۴۷۰	۰/۵۰۸۰	۰/۰۴۵	۰/۰۶۰۰	-۰/۳۰۰	۰/۳۷۰	۰/۶۲۶	۱

* معنی‌داری در سطح ۱٪

آنالیز حساسیت ورودی‌های مدل

پس از نتایج آنالیز همبستگی و مشخص نمودن پارامترهای ورودی مدل‌ها، برای بررسی میزان حساسیت هر کدام از ورودی‌ها به نتایج مدل، آنالیز حساسیت به روش ضریب بدون بعد انجام شد. در این روش، هر یک از متغیرها مقداری تغییر داده می‌شوند و تأثیر آن‌ها بر مقدار خروجی مدل برآورد شده و حساسیت مدل نسبت به متغیر ورودی محاسبه می‌گردد. مقدار حساسیت نسبی از اختلاف خروجی داده‌های اصلی و داده‌های تغییر داده شده، به اختلاف خروجی داده‌های اصلی به‌دست می‌آید. هرچه مقدار حساسیت نسبی برای یک متغیر ورودی بیشتر باشد، اهمیت آن در مدل‌سازی بیشتر بوده و تأثیر بیشتری بر خروجی دارد و بالعکس. جدول ۳ نتایج آنالیز حساسیت برای سه پارامتر SAR ، EC و TDS را نشان می‌دهد.

معیارهای ارزیابی مدل‌ها

برای تعیین میزان دقت مدل‌ها از مقادیر $RMSE$ ، MAE و R^2 استفاده شد. هرچه مقادیر $RMSE$ و MAE به صفر نزدیک‌تر و مقدار R^2 به یک نزدیک‌تر باشد، دقت مدل در شبیه‌سازی بیش‌تر است.

$$RMSE = \sqrt{\frac{1}{n} \sum (y_{\text{observed}} - y_{\text{predicted}})^2} \quad (1)$$

$$MAE = 100 * \frac{1}{n} \sum |y_{\text{observed}} - y_{\text{predicted}}| \quad (2)$$

$$R^2 = 1 - \frac{\sum (y_{\text{predicted}} - y_{\text{observed}})^2}{\sum y_{\text{observed}}^2 - \frac{(\sum y_{\text{observed}})^2}{n}} \quad (3)$$

که در آن‌ها $y_{\text{predicted}}$: مقادیر پیش‌بینی شده، y_{observed} : مقادیر مشاهداتی و n : تعداد داده‌ها است.

یافته‌ها

در این پژوهش به منظور شبیه‌سازی پارامترهای کیفی EC ، SAR و TDS از داده‌های کیفی دشت زبدون به‌صورت ماهانه طی سال‌های ۱۳۹۰ تا ۱۳۹۷ استفاده شد. اطلاعات جمع‌آوری شده برای طراحی دو مدل ANN و $ANN-GA$ شامل: هدایت الکتریکی، نسبت جذب سدیم، اسیدیته، سولفات، کلسیم، منیزیم، سدیم، مقدار کل نمک‌های محلول و بی‌کربنات می‌باشد. مشخصات ورودی پارامترهای کیفی در جدول ۱ نشان داده شده است.

جدول ۱. مشخصات آماری پارامترهای کیفی آب زیرزمینی دشت زبدون

پارامترهای کیفی آب	واحد	کمینه	بیشینه	میانگین	انحراف معیار
نسبت جذب سدیم	...	۰/۷۴	۱۵/۲۱	۹/۱۵	۷/۰۵
هدایت الکتریکی	میکروموس بر سانتی‌متر	۱۴۴۰	۶۹۷۸	۴۷۰/۸۵	۱۱۵/۷
کلسیم	میلی گرم بر لیتر	۱۱۲/۲۵	۳۴۱/۴۱	۱۹/۸۱	۳۳/۸۷
منیزیم	میلی گرم بر لیتر	۲۷/۱	۷۰/۵۱	۵/۶۳	۴/۷۳
سولفات	میلی گرم بر لیتر	۱۷/۴۵	۸۷/۸۲	۴۶/۲۲	۱۱/۰۶
بی‌کربنات	میلی گرم بر لیتر	۲/۰۱	۸/۱۲	۴/۴۳	۱/۵
سدیم	میلی گرم بر لیتر	۰/۴۲	۱۲/۳	۸/۰۷	۹/۱۱
کل جامدات محلول	میلی گرم بر لیتر	۱۰۵۱	۴۷۷۶	۲۹۷۱	۷۱۵/۸۱
اسیدیته	...	۵/۰۴	۷/۹	۷/۶۳	۰/۴۱

شد. تعداد نرون‌های لایه پنهان از ۱ تا ۱۰ و تعداد نرون‌های لایه ورودی از ۱ تا ۵ تغییر داده شد و در هر مرحله مقدار ضریب RMSE و R^2 (به صورت عکس نباشد) بین نقاط شبیه‌سازی شده توسط مدل شبکه عصبی مصنوعی و داده‌های اصلی محاسبه گردید. نتایج حاصل از تکرارهای نرون در لایه پنهان در جدول ۴ ارائه شده است.

جدول ۴. نتایج تکرارها با تعداد نرون‌های مختلف برای لایه پنهان

ANN		تعداد نرون‌ها در لایه پنهان
R ²	RMSE	
۰/۷۹۹	۰/۷۷۱	۱
۰/۸۱۵	۰/۷۳۵	۲
۰/۸۰۱	۰/۷۵۴	۳
۰/۷۸۹	۰/۷۰۹	۴
۰/۸۵	۰/۷۰۱	۵*
۰/۸۲۵	۰/۷۲۱	۶
۰/۸۳۷	۰/۷۴۱	۷
۰/۸۴۱	۰/۷۱۲	۸
۰/۸۳۸	۰/۷۱۹	۹
۰/۸۱۱	۰/۷۲	۱۰

در این پژوهش به منظور شبیه‌سازی پارامترهای کیفی SAR، EC و TDS به مقایسه دو مدل ANN و ANN-GA پرداخته شد. خروجی هر کدام از مدل‌ها برای هر سه پارامتر EC، SAR و TDS برای دو تابع محرک به دست آمد، سپس با توجه به معیارهای ارزیابی مدل، سناریویی که دارای کمترین مقدار خطا در دوره‌های آموزش، صحت‌سنجی و آزمون بود، به عنوان ساختار بهینه انتخاب گردید. پارامترهای دو مدل ANN و ANN-GA به ترتیب با استفاده از سعی و خطا و الگوریتم ژنتیک محاسبه شد. سپس مقادیر MAE، RMSE و R^2 سه پارامتر مذکور با استفاده از مدل‌ها با دو تابع محرک تانژانت سیگموئید و لگاریتم سیگموئید در سه مرحله آموزش، صحت‌سنجی و آزمون در جدول ۵ تا ۷ نشان داده شده است.


جدول ۳. نتایج آنالیز حساسیت پارامترهای کیفی آب زیرزمینی

پارامتر کیفی	پارامتر	حساسیت نسبی
SAR	Ca ²⁺	۰/۸۸۸
	Mg ²⁺	۰/۲۴۱
	HCO ₃ ⁻	۰/۷۹۵
	Na ⁺	۰/۸۵۰
	TDS	۰/۹۶۱
EC	SAR	۰/۲۷۵
	Ca ²⁺	۰/۸۸۹
	Mg ²⁺	۰/۸۰۱
	SO ₄ ²⁻	۰/۹۵۷
	Na ⁺	۰/۶۴۵
TDS	SAR	۰/۹۷۰
	EC	۰/۹۱۴
	Ca ²⁺	۰/۹۰۰
	Mg ²⁺	۰/۵۹۸
	SO ₄ ²⁻	۰/۸۷۴
	Na ⁺	۰/۳۲۱


انتخاب مدل بهینه برای شبیه‌سازی

برای دریافت نتایج دقیق‌تر از مدل شبکه عصبی مصنوعی لازم است که پارامترهای مورد استفاده آن بهینه گردند. برای مشخص نمودن بهترین پارامترهای مدل شبکه عصبی مصنوعی مانند تعداد لایه‌ها، نرون‌ها و وزن لایه‌ها، زمان بسیاری صرف واسنجی آن‌ها با استفاده از روش آزمون و خطا می‌شود. به همین علت در پژوهش حاضر از ترکیب مدل شبکه عصبی مصنوعی و الگوریتم ژنتیک (ANN-GA)، به منظور رسیدن به مقادیر مطلوب پارامترهای مدل شبکه عصبی مصنوعی استفاده شد. در ادامه نتایج حاصل از محاسبه نرون‌ها در دو مدل ANN و ANN-GA به عنوان مثال، ارائه شده است.

در مطالعه حاضر تعداد نرون‌های مختلف برای لایه پنهان و ورودی جهت انتخاب بهترین مدل با کمترین خطا در نظر گرفته



نمودار ۲. مقایسه نتایج حاصل از شبیه‌سازی مدل ANN و ANN-GA با مقادیر اندازه‌گیری شده پارامتر کیفی EC



نمودار ۳. مقایسه نتایج حاصل از شبیه‌سازی مدل ANN و ANN-GA با مقادیر اندازه‌گیری شده پارامتر کیفی TDS

بحث

با توجه به جدول ۲، بیشترین همبستگی پارامتر EC در سطح اطمینان ۰/۹۹ به‌ترتیب مربوط به کلسیم، منیزیم، سولفات، سدیم و نسبت جذب سدیم و همچنین بیشترین همبستگی به پارامتر TDS به‌ترتیب مربوط به سدیم، هدایت الکتریکی، کلسیم، منیزیم، سولفات و نسبت جذب سدیم بود. برای پارامتر کیفی SAR هم بالاترین میزان همبستگی مربوط به سدیم، کل نمک‌های محلول، بی‌کربنات، کلسیم و منیزیم بود. بنابراین پارامترهای ورودی مدل‌ها برای پارامتر کیفی TDS شامل: سدیم، هدایت الکتریکی، کلسیم، منیزیم، سولفات و نسبت جذب سدیم و برای پارامتر کیفی SAR شامل: سدیم، کل نمک‌های محلول، بی‌کربنات، کلسیم و منیزیم و برای پارامتر کیفی EC شامل: کلسیم، منیزیم، سولفات، سدیم و نسبت جذب سدیم بود. در مطالعه سلطانی محمدی و همکاران که در دشت رامهرمز انجام شد، بیشترین همبستگی پارامتر EC در سطح اطمینان ۰/۹۹ به‌ترتیب

جدول ۵. نتایج حاصل از مدل‌های ANN و ANN-GA در شبیه‌سازی پارامتر SAR

مدل	تابع محرک	تست			صحت‌سنجی	
		RMSE	MAE	R ²	R ²	R ²
ANN	Tan sig	۱۷/۲۵	۱۷/۹۱	۰/۸۶	۰/۸۸	۰/۸۹
ANN	Log sig	۱۹/۴۴	۱۸/۱	۰/۸۴	۰/۸۵	۰/۸۸
ANN-GA	Tan sig	۹/۱۵	۱۰/۷۵	۰/۹۸	۰/۹۸۸	۰/۹۹
ANN-GA	Log sig	۱۰/۳۶	۱۰/۵	۰/۹۶۸	۰/۹۷۱	۰/۹۸


جدول ۶. نتایج حاصل از مدل‌های ANN و ANN-GA در شبیه‌سازی پارامتر EC

مدل	تابع محرک	تست			صحت‌سنجی	
		RMSE	MAE	R ²	R ²	R ²
ANN	Tan sig	۲۱/۴	۲۳/۱	۰/۸۴۵	۰/۸۵۷	۰/۸۶
ANN	Log sig	۱۷/۰۴	۱۹/۴۷	۰/۸۵۹	۰/۸۷۸	۰/۸۹
ANN-GA	Tan sig	۱۱/۷۷	۱۰/۵۱	۰/۹۷۵	۰/۹۸۹	۰/۹۸۱
ANN-GA	Log sig	۱۲/۳۶	۱۱/۴۸	۰/۹۶۱	۰/۹۷۷	۰/۹۷۵

جدول ۷. نتایج حاصل از مدل‌های ANN و ANN-GA در شبیه‌سازی پارامتر TDS

مدل	تابع محرک	تست			صحت‌سنجی	
		RMSE	MAE	R ²	R ²	R ²
ANN	Tan sig	۱۷/۱۸	۱۷/۰۲	۰/۸۶۹	۰/۸۷۷	۰/۸۹
ANN	Log sig	۱۸/۲۱	۱۹/۰۳	۰/۸۴۸	۰/۸۵۱	۰/۸۶۷
ANN-GA	Tan sig	۱۱/۲	۱۲/۲۵	۰/۹۷۳	۰/۹۸۱	۰/۹۸۸
ANN-GA	Log sig	۸/۲۳	۱۰/۱۱	۰/۹۸۶	۰/۹۹۴	۰/۹۹۸

نمودارهای ۱ تا ۳ نتایج شبیه‌سازی پارامترهای کیفی، SAR، EC و TDS با استفاده از مدل‌های ANN و ANN-GA را نشان می‌دهد.



نمودار ۱. مقایسه نتایج حاصل از شبیه‌سازی مدل ANN و ANN-GA با مقادیر اندازه‌گیری شده پارامتر کیفی SAR

مربوط به کلسیم و سولفات، بیشترین همبستگی به پارامتر TDS به ترتیب مربوط به سدیم، کلسیم، هدایت الکتریکی، نسبت جذب سدیم و سولفات و بیشترین همبستگی SAR مربوط به سدیم و کل نمک‌های محلول بود (۱۴).

هیل در پژوهش‌های خود بیان می‌کند که اگر مقدار ضریب حساسیت پارامتری بیش‌تر از ۰/۱ باشد، آن پارامتر جزء پارامترهای حساس مدل محسوب می‌شود (۱۵، ۱۶). با توجه به جدول ۳، حساس‌ترین پارامترها در مدل شبیه‌ساز SAR به ترتیب مربوط به مقدار کل نمک‌های محلول، سدیم، کلسیم، بی‌کربنات و منیزیم، در مدل شبیه‌ساز EC حساس‌ترین پارامترها به ترتیب سولفات، کلسیم، منیزیم، سدیم و نسبت جذبی سدیم و در نهایت حساس‌ترین پارامترهای مدل شبیه‌ساز TDS به ترتیب نسبت جذب سدیم، هدایت الکتریکی، کلسیم، سولفات، منیزیم و سدیم بود. در پژوهش آه‌نین‌جان و آگدرنژاد که از ضریب بدون بعد به منظور آنالیز حساسیت پارامترهای ورودی استفاده کردند، حساس‌ترین پارامترها در مدل شبیه‌ساز SAR به ترتیب مربوط به مقدار کل نمک‌های محلول، سدیم، بی‌کربنات، اسیدیته و هدایت الکتریکی، در مدل شبیه‌ساز EC حساس‌ترین پارامترها به ترتیب سولفات، کلسیم، منیزیم، اسیدیته، سدیم و نسبت جذبی سدیم و در نهایت حساس‌ترین پارامترهای مدل شبیه‌ساز TDS به ترتیب هدایت الکتریکی، نسبت جذب سدیم، سولفات، کلسیم، منیزیم و سدیم بود (۱۶).

با توجه به جدول ۳، تعداد بهینه نرون در لایه پنهان برای مدل شبکه عصبی مصنوعی برابر ۵ بود. تمام مراحل فوق جهت انتخاب تعداد نرون‌های لایه ورودی با تعداد لایه‌های پنهان مشخص شده، انجام شد که کمترین خطا در مدل شبکه عصبی مصنوعی با تعداد نرون ورودی ۳ برآورد شد. در مدل ترکیبی با الگوریتم ژنتیک، تعداد نرون‌های بهینه در لایه پنهان و ورودی به ترتیب ۷ و ۵ به دست آمد.

با توجه به جدول ۵ و ۶، در مدل ANN و ANN-GA بیشترین دقت شبیه‌سازی SAR در مدل با تابع تانژانت سیگموئید و در مدل شبیه‌ساز EC نیز بیشترین دقت در مدل‌های ANN و ANN-GA

به ترتیب مربوط به توابع محرک لگاریتم سیگموئید و تانژانت سیگموئید بود. همچنین با توجه به جدول ۷، در مدل ANN و ANN-GA بیشترین دقت شبیه‌سازی TDS به ترتیب در مدل با توابع محرک تانژانت سیگموئید و لگاریتم سیگموئید به دست آمد؛ به طوری که مقدار RMSE و MAE کمترین مقدار و شاخص R^2 بیشترین مقدار را داشت. به طور کلی با توجه به نتایج جداول ۵ تا ۷، دقت مدل ANN-GA هم بالاتر از مدل ANN، برای شبیه‌سازی پارامترهای کیفی آب زیرزمینی دشت زیدون برآورد شده است.

همانطور که در نمودارهای ۱ تا ۳ مشاهده می‌گردد، بیشترین هم‌پوشانی با مقادیر اندازه‌گیری شده مربوط به مدل ANN-GA بود. الگوریتم ژنتیک مزایایی ویژه‌ای دارد که باعث بهبود عملکرد مدل شبکه عصبی مصنوعی می‌گردد که در ادامه به آن‌ها اشاره می‌شود. ۱- جستجوی چندجانبه و کار بر روی جمعیتی از متغیرها در آن واحد: الگوریتم ژنتیک در یک جمعیت از جواب‌ها و با مجموعه‌ای از آن‌ها شروع به جستجو می‌کند و با یک جواب عمل نمی‌کند. در این الگوریتم به جای یافتن نقطه مناسب، محدوده مناسب شناسایی و با انتخاب والدین مناسب از تمامی فضای متغیرها، یک جستجوی مؤثر برنامه‌ریزی می‌شود. این در حالی است که در اکثر الگوریتم‌های بهینه‌سازی، جستجو از یک نقطه شروع و با یک الگوریتم به نقطه دیگر هدایت می‌گردد. روش ذکر شده ممکن است منجر به پاسخ موضعی گردد و از یافتن پاسخ بهینه بازماند. ۲- استفاده از مقدار تابع هدف برای جستجو: در این روش نیازی به اطلاعات جانبی مانند مشتق تابع نیست. به دلیل راحتی کاربرد آن می‌توان برای بهینه‌سازی توابع منفصل و دارای چند نقطه بهینه استفاده نمود. ۳- استفاده از قواعد احتمالی به جای قواعد قطعی: الگوریتم ژنتیک به صورت هم‌زمان با مجموعه‌ای از نقاط کار می‌کند و به طور موازی از ماکزیمم‌های مختلف فراتر رفته و بنابراین احتمال رسیدن به جواب اشتباه کاهش می‌یابد. قواعد احتمالی به معنای جستجوی تصادفی نیست، بلکه این الگوریتم از انتخاب تصادفی به عنوان ابزاری برای هدایت عمل جستجو استفاده می‌نماید. ۴- انعطاف‌پذیری بالا: الگوریتم ژنتیک به دلیل خاصیت

بالا دارند.

ملاحظات اخلاقی

نویسندگان تمام نکات اخلاقی شامل عدم سرقت ادبی، انتشار دوگانه، تحریف داده‌ها و داده‌سازی را در این مقاله رعایت کرده‌اند. همچنین هرگونه تضاد منافع حقیقی یا مادی که ممکن است بر نتایج یا تفسیر مقاله تأثیر بگذارد را رد می‌کنند.

تشکر و قدردانی

این مقاله بخشی از پایان نامه مقطع کارشناسی ارشد رشته مهندسی عمران گرایش مدیریت منابع آب با کد شناسایی ۱۰۶۲۹۱۹۷۱۶۴۸۹۹۱۱۳۹۹۱۶۲۳۴۲۶۶۲ در دانشگاه آزاد اسلامی واحد اهواز می‌باشد. بدین‌وسیله از مسئولین محترم دانشگاه آزاد اسلامی واحد اهواز جهت همکاری در انجام این پژوهش تشکر و قدردانی می‌شود.

تکاملی، جواب‌ها را بدون توجه به طرز کار ویژه مسأله جستجو و می‌تواند با انواع تابع هدف در هر فضای جستجو عمل نماید. رضایی و همکاران دقت مدل شبکه عصبی تلفیق شده با الگوریتم ژنتیک برای پیش‌بینی سطح ایستابی دشت عباس را تأیید نمودند (۱۷). جلال کمالی و همکار و دش و همکاران نیز عملکرد بالای مدل شبکه عصبی مصنوعی ترکیبی با الگوریتم ژنتیک را برای تخمین پارامترهای آب زیرزمینی تأیید نمودند (۱۸، ۱۹).

نتیجه‌گیری

نتایج این پژوهش به‌طور کلی نشان داد دقت شبیه‌سازی پارامترهای کیفی آب زیرزمینی دشت زیدون در مدل ANN-GA بالاتر از مدل ANN می‌باشد. بنابراین استفاده از مدل شبکه عصبی مصنوعی تلفیقی با الگوریتم ژنتیک، ابزاری مناسب برای شبیه‌سازی پارامترهای کیفی آب زیرزمینی در حجم بالا، بدون احتیاج به اندازه‌گیری و کارهای آزمایشگاهی است که نیاز به زمان و هزینه

References

1. Mirzaei A.A, Nazemi A.H. Predicting groundwater level using artificial neural networks. First National Conference on Coastal Land Water Resources Management, Sari, University of Agricultural Sciences and Natural Resources, Sari. 2009 (In Persian).
2. Dehghani A.A, Asgari M, Mosaedi A. Comparison of three methods of artificial neural network, fuzzy inference system, adaptive neural system and geostatistics among groundwater level detection (Case study of Qazvin plain). Journal of Agricultural Sciences and Natural Resources. 2008; 16 (1): 517-528 (In Persian).
3. Daryaei M, Eigder Nejad A, Bina M, Radmanesh F. Effect of river water quality factors on EC and TDS using artificial neural networks. 8th Seminar on River Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran. 2010 (In Persian).
4. Luk KC, Ball J.E, Sharma A. An application of artificial neural network for rainfall forecasting. Mathematical and Computer Modelling. 2001; 33 (6-7): 683-693.
5. Sayadi Shahraki A, Soltani Mohammadi A, Naseri A.A. and Mokhtaran A. Simulation of groundwater salinity using Artificial Neural Network (ANN), Particle Swarm Optimization (PSO) and model SEAWAT (Case study: Debal khazaie sugarcane plantation). Journal of Water and Soil Conservation. 2017; 23(5), 307-316 (In Persian).
6. Rooki R, Ariyafar A, Adeli Nasab J. Investigation of groundwater quality in Gonabad plain aquifer of Khorasan Razavi using multivariate statistical methods and artificial intelligence. Journal of Mineral Resources Engineering. 2017; 2 (1): 49-61(In Persian).
7. Kanda E.K, Kipkorir E.C, Kosgei J.R. Dissolved oxygen modelling using artificial neural network: a case of river nzoia, lake victoria basin, kenya. Journal of Water Security. 2016; 2 (1): 1-7.
8. Montaseri M, Ghavidel S.Z, Sanikhani H. Water quality variations in different climates of Iran: toward modeling total dissolved solid using soft computing techniques. Stochastic Environmental Research and Risk Assessment,. 2018; 32 (8): 2253-2273.
9. Dayhoff J.E. Neural Network Principles. Prentice-Hall International, U.S.A. 1990.
10. Khanna T. Foundation of neural networks. Addison-Wesley Publishing Company, U.S.A. 1990.
11. Goldberg D.E. Genetic Algorithms in Search Optimization and Machine Learning. Addison-Wesley. 1989.
12. Musavi-Jahromi S.H, Golabi M. Application of artificial neural networks in the river water quality modeling: Karoon river, Journal of Applied Sciences. 2008; 8 (12): 2324-2328.
13. Banejad H, Kamali M, Amirmoradi K, Olyae F. Forecasting Some of the Qualitative Parameters of Rivers Using Wavelet Artificial Neural Network Hybrid (W-ANN) Model (Case of study: Jajroud River of Tehran and Gharaso River of Kermanshah). Journal Health & Environ. 2013; 6(3), 277-294 (In Persian).
14. Soltani Mohammadi A, Sayadi Shahraki A, Naseri A.A.

- Simulation of Groundwater Quality Parameters Using ANN and ANN+PSO Models (Case Study: Ramhormoz Plain). *Journal of Pollution*. 2016; 3(2), 191-200.
15. Hill M. Methods and guidelines for effective model calibration. U.S. Geological survey Water- Resources Investigations Rep. 1998; 98-4005.
16. Ahaninjan K, Egdernezhad A. Modeling Qualitative Parameters of SAR, EC, and TDS in Groundwater using Optimized Artificial Neural Network Model (Case Study: Behbahan Plain). *Journal of Environment and Water Engineering*. 2020; 6(2), 161-172 (In Persian).
17. Rezaee M.J, Rezaee M.R, Rezaee J. Estimation of Groundwater Level Changes Using Four Different Evolutionary Neural Network Techniques, Case Study: Dasht-e Abbas, Ilam Province. *Journal of Watershed Engineering and Management*. 2020; 12 (3): 737-755 (In Persian).
18. Jalalkamali A, Jalalkamali N. Groundwater modeling using hybrid of artificial neural network with genetic algorithm. *African Journal of Agricultural Research*. 2017; 6 (26): 5775-5784.
19. Dash N.B, Panda S.N, Remesan R, Sahoo N. Hybrid neural modeling for groundwater level prediction. *Neural Computing and Applications*. 2010; 19(8): 1251-1263.